


Helsinki 17.10.2003

ETUOIKEUSTODISTUS  
PRIORITY DOCUMENT



Hakija  
Applicant  
Honeywell Oy  
Jyväskylä

Patenttihakemus nro  
Patent application no  
20021578

Tekemispäivä  
Filing date  
03.09.2002

Kansainvälinen luokka  
International class  
G06T

Keksinnön nimitys  
Title of invention

"Paperin karakterisointi"

Täten todistetaan, että oheiset asiakirjat ovat tarkkoja jäljennöksiä Patentti- ja rekisterihallitukselle alkuaan annetuista selityksestä, patenttivaatimuksista, tiivistelmästä ja piirustuksista.

This is to certify that the annexed documents are true copies of the description, claims, abstract and drawings originally filed with the Finnish Patent Office.

*Marketta Tehikoski*  
Marketta Tehikoski  
Apulaistarkastaja

**PRIORITY DOCUMENT**  
SUBMITTED OR TRANSMITTED IN  
COMPLIANCE WITH  
RULE 17.1(a) OR (b)

Maksu 50. €  
Fee 50 EUR

Maksu perustuu kauppa- ja teollisuusministeriön antamaan asetukseen 1027/2001 Patentti- ja rekisterihallituksen maksullisista suoritteista muutoksineen.

The fee is based on the Decree with amendments of the Ministry of Trade and Industry No. 1027/2001 concerning the chargeable services of the National Board of Patents and Registration of Finland.

Osoite: Arkadiankatu 6 A Puhelin: 09 6939 500 Telefax: 09 6939 5328  
P.O.Box 1160 Telephone: + 358 9 6939 500 Telefax: + 358 9 6939 5328  
FIN-00101 Helsinki, FINLAND

## Paperin karakterisointi

Keksintö liittyy paperin laadun karakterisointiin ja luokitukseen käyttämällä konenäköä tai muuta kaksiuotteisesti kuvaavaa menetelmää.

5

Hakemuksen liitteenä on kirjallisuusluettelo, johon viitataan hakasulkuihin merkityillä viitenumeroilla. Tunnettuun tekniikkaan viitataan viitejulkaisujen muodossa aina kunkin asian yhteydessä.

- 10 Keksinnön tarkoituksena on saada aikaan paperin laadun karakterisointimenetelmä, joka antaa nykyisiä menetelmiä luotettavamman luokituksen ilman inhimillisistä tekijöistä johtuvaa vaihtelua.

- 15 Tunnettua tekniikkaa edustavat konenäköön perustuvat paperin laadutusjärjestelmät ovat aikaisemmin pohjautuneet ohjattuihin oppimismenetelmiin sekä vanhoihin ja tehottomiin kuvista laskettaviin piirteisiin. Piirteinä on yleensä käytetty yhteisesilintymämatriseksi saatavia mittoja, tehospeskrriana-lyysisä sekä specific perimeter -piirrettä. Myös kuvien harmaasävyjen keskiarvon ja varianssin on oletettu kuvaavan paperin neliömassan vaihteluita.
- 20 teistä on muodostettu numeerinen mitta, joka kuvaa paperin laatua. Tämän numeerisen mittan perusteella on sitten luokiteltu paperin formaatiota tai muita ominaisuuksia. [1, 2, 3, 4, 5]

- 25 Vanhat tekstuuripiirteet eivät kykene antamaan paperin tekstuurista kovin-kaan tarkkaa tietoa ja ne ovat herkkiä olosuhteiden, kuten valaistuksen, muutoksille. Kun heikosti diskriminoivat piirteet yhdistetään ohjattuun luokitteijan opettamiseen, heikkenee järjestelmän karakterisointikyky entisestään. Tämä johtuu siitä, että perinteiset ohjatut menetelmät ovat erittäin herkkiä ihmisen tekemille virheille. Ihmiset tekevät yleensä virheitä opetusnäytteiden
- 30 valinnassa ja niiden nimeämisessä. Lisäksi ihmisten tekemät valinnat ovat subjektiivisia ja siten eri ihmisten tulkinnat eroavat toisistaan. Laaduntarkas-

tuksen kannalta tämä ei ole toivottavaa. Ohjattuihin oppimismenetelmiin pohjautuvan järjestelmän uudelleenopetus on vaikeaa jos olosuhteiden muutokset tätä vaativat. Usein näin on, sillä kehittymättömät tekstuuripiirteet ovat erittäin herkkiä olosuhteissa tapahtuville muutoksille.

5

Ongelmana on ollut se, että paperia on analysoitu heikosti diskriminoivilla tekstuuripiirteillä. Lisäksi jo ennestään pirstoutuneesta ja ei-normaaliajakautuneesta piirreavaruudesta on pyritty selvittämään luokkarajoja parametrisilla menetelmillä. Luokittelijoita operattaessa ja luokkarajojen etsimisessä on käytetty ohjattuja menetelmiä, mikä lisää virheiden määrää.

10

Paperin karakterisoinnissa pyritään lajittelemaan keskenään ominaisuuksiltaan samanlaiset paperit samaan kategoriaan. Paperia voidaan kuvata kokosen valmistuksen ajan, näin saadaan tietoa myös siitä, mitkä olivat hyvän laatu-  
huonon paperin ominaisuudet valmistusprosessin eri vaiheissa. Ilman karakterisointia ei pelkkien kuvien perusteella pystytä hakemaan prosessista hyödyllistä informaatiota, koska kuvien arviointi ja luokittelu on ihmiselle hyvin vaikeaa ja subjektiivista, lisäksi suuren datamäärän käsittely on mahdotonta ilman automaattista, numeroarvoihin tai symboleihin perustuvaa luokitusta.  
Karakterisoinnin avulla saadaan paperin laatu luokiteltua useisiin luokkiin, joiden perusteella pystytään jäljittämään tuotantoprosessin toimintaa ja yrittää parantaa haluttuja ominaisuuksia paperissa, kunhan tiedetään mitkä tekijät vaikuttavat paperin laatuun, ja millaista paperi on ollut missäkin tuotannon vaiheessa. Itse karakterisoinnin ei tarvitse ottaa kantaa paperin laatuun, riittää kunhan samanlaiset paperit saa saman luokan. Luokituksen mukaan voidaan ohjata prosessia tai lajitella paperia laatu luokkiin.

20

25

Konenäkömenetelmissä paperikuvista pyritään laskemaan joukko piirteitä, jotka kuvaavat paperin ominaisuuksia mahdollisimman tarkasti [1, 2, 3, 4, 5].  
Tyypillisiä ominaisuuksia ovat esimerkiksi paperin painettavuus ja vetolujuus. Laskettavat piirteet ovat numeerisia mittoja ja ne muodostavat moniulottei-

30

seen piirreavaruuteen pirstoutuneita klustereita. Piirreavaruus voi olla erillään moniulotteinen, ja on selvää, että eri paperilaatua kuvaavat piirteet on vaikea löytää pirstoutuneesta avaruudesta. Kuvassa 1 on esimerkki piirreavaruudesta, joka esitetään yksin-kertaisuuden vuoksi kaksiulotteisessa koordinaatistossa. Kuvassa olevat rastit kuvaavat piirteiden arvoja, ja kuvaan vedetty viiva mahdollista paperin painettavuusominaisuuksien muuttumista.

Selityksessä viitataan seuraaviin kuviin:

10 Kuvassa 1 on esitetty piirteiden pirstoutuminen ja ominaisuuksien raja.

Kuvassa 2 on esitetty moniulotteisen piirredatan klusteroituminen kaksiulotteiseen koordinaatistoon.

15 Kuvassa 3 on keksinnön mukaisen luokittelun periaatekaavio

Kuvassa 4 on esitetty 3x3 -kokoisen LBP-piirteen laskeminen.

20 Kuvassa 5 on esitetty pisteen ympyrän kehällä oleva naapurusto, josta LPB-piirre lasketaan.

Kuvassa 6 on esitetty SOM:n käyttö luokittelijana

75 Kuvassa 7 on kaavio kuva tuotannon aikana suoritettavasta paperin karakterisoinnista.

30 Perinteiset parametriset menetelmät eivät kykene löytämään tarkasti eri paperilaatujen rajoja, sillä ne tekevät oletuksia datan jakautumisesta. Keksinnön mukaisessa menetelmässä datalle tehdään aluksi kuvaus kaksiulotteiseen koordinaatistoon. Jokaiselle klusterille annetaan leima sen perusteella, minkä laatuista paperia klusteri edustaa. Eli paperin laadusta voidaan tehdä

päätelmiä sen perusteella minne näyte kaksiulotteisessa koordinaatistossa sijoittuu. Kuvassa 2 on esimerkki moniulotteisen piirreavaruuden kuvaamisesta kaksiulotteiseen koordinaatistoon menetelmällä, joka säilyttää datan paikallisen rakenteen ja näytteiden väliset keskinäiset etäisyydet [6, 7, 8, 9, 10].

- 5 Leimat 3a – 3d kuvaavat paperin eri ominaisuuksia, samalla leimalla merkitylle alueelle luokiteltu paperi on kyseisen ominaisuuden suhteen samantapaista muiden saman luokan papereiden kanssa. Leimat annetaan jälkikäteen, ja esimerkiksi vetolujuudelle, kiiltoasteelle tai painettavuudelle tulee yleensä eri aluejako ja luonnollisesti eri leimat.

10

Menetelmässä data järjestäytyy automaattisesti siten, että näytteiden keskinäiset sijainnit uudessa koordinaatistossa ovat samat kuin alkuperäisessä moniulotteisessa piirreavaruudessa. Paperilaaduista voidaan tehdä luotettavia päätelmiä sen perusteella minne se uudessa koordinaatistossa sijoittuu. Da-

- 15 tan jakaumista ei tehdä aluksi minkäänlaisia oletuksia ja se voi olla minkäläistä tahansa. Erilaisen tekstuurin omaavat paperit voivat silti omata samanlaiset paino-ominaisuudet. Tämä voidaan huomioida leimattaessa eri klustereita. Tehokkailla tekstuuripiirteillä, kuten LBP:llä, paperin pintakuviointia voidaan analysoida erittäin tehokkaasti [11, 12].

20

Nyt esitettävässä keksinnössä yhdistetään ohjaamaton oppimismenetelmä, tehokkaat harmaasävyinvariantit tekstuuripiirteet sekä moniulotteisen piirre-

25 datan havainnollinen visuaalisointi piirreavaruuden ulottuvuuksia vähentämällä. Menetelmässä ihmisen ei tarvitse tehdä oletuksia ja päätelmiä opetusmateriaalista, vaan opetusdata järjestäytyy automaattisesti ominaisuuksiensa mukaan. Moniulotteinen piirreavaruus kuvautuu havainnolliseen muotoon ja näytteiden sijaintia piirreavaruudessa voidaan visualisoida.

30

Uudet kehittyneet tekstuurimenetelmät antavat tarkkaa tietoa tekstuurin mikro-rakenteesta. Tällaisia harmaasävyinvariantteja tekstuuripiirteitä ovat esimerkiksi paikallisia binäärikuviota mittaavat LBP-piirteet ja sen muunnokset

## 5

[11, 12]. Tutkittaessa paperin pintaa näillä piirteillä, saadaan selvitettyä tärkeitä ominaisuuksia paperista. Yhdistelemällä tehokkaat tekstuuripiirteet ohjaamattomaan oppimismenetelmään voidaan laadutustarkkuutta parannettua huomattavasti.

5

Menetelmän kaaviokuva on esitetty kuvassa 3. Opetusjoukosta 11 lasketaan aluksi tekstuuripiirteitä vaiheessa 12, joita käytetään luokittelijan 13 opettamiseen. Moniulotteisen piirre-avaruuden ulottuvuuksia vähennetään, jotta sitä voidaan visualisoida havainnollisesti. Luokittelu suoritetaan myös käyttäen uutta piirreavaruutta 14. Ihmisen tehtäväksi jää siis nimetä ja valita luokitellut alueet vaiheet ja saattaa ne helpommin ymmärrettävään muotoon tai saattaa paperilaadut hyvyysjärjestykseen niin, että niiden mukaan voidaan myöhemmin säätää prosessia. Ihmisen tehtävänä on myös valita opetusjoukko niin, että saadaan edustava otos erilaisia paperelta. Näitä tehtäviä on kuvattu viitenumeroilla 15,16,17 ja 18.

Menetelmässä paperin ominaisuudet kuvataan ensin tehokkailta tekstuuripiirteillä, mikä vähentää huomattavasti piirreavaruuden pirstoutumista. Moniulotteinen piirre-avaruus kuvataan vähempiulotteiseen koordinaatistoon siten, että datan paikallinen rakenne säilyy. Vähempiulotteisessa koordinaatistossa olevat klusterit edustavat eri laatuisia papereita. Eri klusterit nimelään sen mukaan mitä paperilaatua kyseinen klusteri edustaa. Tämän jälkeen uuteen koordinaatistoon voidaan luokitella eri laatuisia papereita etsimällä klusteri, johon tarkasteltava paperi klusteroituu. Klusteroituneen piirreavaruuden kaaviokuva on esitetty kuvassa 2.

Piirteet voidaan irrottaa esimerkiksi käyttämällä paikallisiin binaarikuvioihin perustuvia tekstuurimittoja. LBP (Local Binary Pattern) -piirteet kuvatason paikallisessa ympäristössä esiintyvää kuviointia [11, 12]. Alkuperäinen LBP-piirre [11] on esimerkiksi 3x3-ympäristöstä laskettava tekstuuripiirre, jonka laskemista on havainnollistettu kuvassa 4. Kuvan esimerkissä 3x3-ympäristö

31 kynnystetään (nuoli 11) ympäristön keskipisteen (CV) harmaasävyyn mukaan kaksitasoiseksi 32: kynnystysarvoa CV suuremmat tai sen kanssa samansuuruiset pikselit saavat arvon 1, ja pienemmät kynnestyvät 0:ksi. Kynnystämisen jälkeen saadut arvot 32 kerrotaan (nuoli 42) LBP-operaattorilla 5 33, jolloin saadaan tulomatriisi 34, jonka alkiot lasketaan yhteen (nuoli 44), jolloin saadaan muodostettua LBP:n arvo. Toinen tapa ajatella LBP:n laske- minen on muodostaa 8-bittinen koodisana suoraan kynnystetystä ympäristös- tä. Esimerkin tapauksessa koodisana olisi 10010101<sub>2</sub>, joka on kymmenkanta- järjestelmässä 149.

10

LBP-piirteistä on myös muodostettu erilaisia moniresoluutio- ja kiertoinva- rianttimalleja [12]. Lisäksi erilaisten binäärikuvioiden vaikutusta LBP- operaattorin suorituskykyyn on tutkittu, jolloin on mahdollistettu tiettyjen kuvioiden poisjättäminen piirrejakaumaa muodostettaessa [12]. Näin LBP- 15 piirrejakauma on saatu lyhyemmäksi.

Moniresoluutio-LBP tarkoittaa sitä, että pisteen naapurusto on valittu use- ammalta eri etäisyydeltä. Etäisyys voi periaatteessa olla mikä tahansa positiivinen luku ja laskennassa käytettävien pisteiden lukumäärä voi myös vaihdel- 20 la etäisyyden mukaan. Kuvassa 5 on esitetty pisteen naapurusto etäisyydellä neljä ( $d=4$ ). Pisteen ympärille on piirretty ympyrä, jonka säde on sama kuin valittu etäisyys. Ympyrän kehältä valitaan näytteitä kulman  $\alpha$ :n osoittamien väleihin siten, että  $N\alpha = 2\pi$ , missä  $N$  on valittujen näytteiden lukumäärä. Jos ympyrän kehällä oleva näyte ei satu tarkasti jonkun pikselin kohdalle tehdään 25 sille interpolointi, jolla pisteen koordinaatit saatetaan vastaamaan kehällä olevia koordinaatteja. Tyypillisesti käytettävät etäisyydet ovat 1, 2 ja 3, sekä näytteiden lukumäärät vastaavasti 8, 16 ja 24. Mitä enemmän pisteitä valitaan, sitä suurempi saatu LBP-jakauma on. 24-ulotteinen piirreavaruus tuottaa jo yli 16 miljoonaa pylvästä sisältävän LBP-jakauman.

30

- Suurten LBP-jakaumien käyttäminen laskennassa on hankalaa. Jakauma saadaan pienemmäksi ja laskennan kannalta järkevän kokoiseksi huomioidulla LBP-koodeista ainoastaan tietty, ennalta valittu, osa. Valitut koodit ovat niin sanottuja jatkuvia binäärikodeja, joissa ympyrän kehällä olevat luvut sisältävät korkeintaan kaksi bittivaihdosta 0:sta 1:een tai päinvastoin. Näin ollen valitut koodisanat sisältävät pitkiä nollien tai ykkösten muodostamia yhtenäisiä ketjuja. Kondien valinta perustuu tietoon, että tietyillä LBP-kuviolla voidaan ilmaista jopa yli 90 % tekstuurissa olevasta kuvioinnista. Käyttämällä laskennassa ainoastaan näitä jatkuvia binääriketjuja saadaan 8 näytteen LBP-jakauma pienemmään 256:sta 58:aan. 16 näytteen LBP-jakauma pienenee puolestaan reilusta 65 tuhannesta 242:een ja 24 näytteen jakauma yli 16 miljoonasta 554:ään. [12]

- Kiertoinvarianttien LBP-piirteiden laskemiseen otetaan mukaan ennalta valittu LBP-kuvien alajoukko [12]. Kuviot ovat valittu siten, että ne ovat invariantteja tekstuurissa tapahtuvalle kiertymiselle. Kiertoinvarianttien LBP-piirteiden käyttäminen ei-invariantissa ongelmassa laskee piirteiden suorituskyyä. Paperin karakterisointi ei kuitenkaan ole kiertoInvariantti ongelma.

- Luokittelu ja klusterointi voidaan tehdä esimerkiksi käyttämällä itseorganisointiin karttoihin perustuvaa tekniikkaa [13]. Itseorganisointi kartta, SOM, on keinotekoisin neuroverkkoihin perustuva ohjaamattoman oppimisen menetelmä. SOM mahdollistaa moniulotteisen tiedon esittämisen ihmiselle havainnollisemmassa, yleensä kaksiulotteisessa, muodossa.

- SOM pyrkii esittämään datan siten, että näytteiden väliset etäisyydet uudessa kaksiulotteisessa koordinaatistossa vastaavat mahdollisimman hyvin todellisia näytteiden välisiä etäisyyksiä niiden alkuperäisessä koordinaatistossa. SOM ei erikseen pyri etsimään ja esittämään datasta sen sisältäviä ryhmittymiä, vaan esittää arvion datan todennäköisyyksiheydestä mahdollisimman uskottavasti säilyttäen sen paikallisen rakenteen. Tämä tarkoittaa sitä, että jos kaksiulot-



teisella kartalla on nähtävissä tiheitä näyttöiden muodostamia ryhmittymiä, niin myös todellisuudessa nämä näytteet sijaitsevat piirreavaruudessa toisi-  
aan lähellä. [13]

- 5 Jotta SOM:ia voitaisiin käyttää ryhmittelemään tietäntyyppistä dataa, läyby-  
se ensin opettaa. SOM opetetaan iteratiivisella ohjaamattomalla menetelmäl-  
lä [13]. SOM:n opetuksen jälkeen jokaiselle kartan solmulle on asetelluna  
jokin piste moniulotteisessa avaruudessa, jota solmu vastaa. Algoritmi on  
säättänyt kartan opetusnäytteiden avulla. Moniulotteiset vektorit muodostavat  
10 epälineaarisen projektion kaksiulotteiseen koordinaatistoon mahdollistaen  
ryhmittymien selkeän visualisoinnin [13].

- SOM:n käyttäminen luokittelijana perustuu samankaltaisten näyttöiden ryh-  
mittymiseen lähekkäin toislaan, jolloin ne voidaan rajata omiksi luokikseen  
15 kartalta. Kaukana toisistaan olevien solmujen näytteet ovat keskenään erilai-  
sia, jolloin ne voidaan erottaa kuuluvan eri luokkiin. Kuvassa 4 on esitetty  
hyvän ja huonon paperin ryhmittymisen kartan vastakkaisiin nurkkiin. Kuvas-  
sa 6 on esitetty SOM:n käyttöä luokittelijana. Kuvan näytteet 61, 62 luokitlu-  
vat luokkiin 63, 64. Karkeana esimerkkinä on käytetty hyvän paperin 61 luu-  
20 kittumista luokka-alueelle 63, ja Huonon paperin luokittumista alueelle 64.  
On huomattava että sekä hyvän, että huonon paperin alueita voi olla useita  
piirstoutuneena eri osille esimerkiksi kaksiulotteisista avaruudesta. Kuitenkin niin,  
että esimerkiksi alueelle 64 luokituttava paperi on kaikki samalla tavalla huo-  
noa. On ymmärrettävää, että tieto paperin valmistajalle on erittäin hyödyllistä  
25 tietää, missä oloissa syntyy mainittuja paperia, jolla voidaan välttää huo-  
noa laatua tuottavia olosuhteita luolannossa. Tämä on mahdollista seuraa-  
malla luolannon parametreja ja luokittamalla jatkuvasti paperin laatua, joi-  
loin opitaan prosessin toiminnasta uutta. ON myös mahdollista syöttää pro-  
sessin parametrit ja paperin luokittelun tulokset toiseen SOM-luokittelijaan,  
30 jolloin saadaan aikaan virheistä oppiva järjestelmä, jota voidaan käyttää pro-  
sessin valvonnan apuna. Tällöin saadaan lopputulokseksi luokittelu joka ku-

vaa tuotannon olosuhteita suhteessa paperin laatuun. Järjestelmä siis oppii esimerkiksi satojen muuttujien vaikutusta paperin laatuun.

- 5 Edellä on selostettu keksinnön mukaista luokittelua käyttäen SOM-luokittelua, mutta mikä tahansa valvomaton klusterointimenetelmä sopii käytettäväksi keksinnön mukaisesti luokitteluun, esimerkiksi LLE, ISOMAP, GTM tekniikat, jotka eivät ole varsinaisia neuroverkkotekniikoita.

- 10 Menetelmä sopii käytettäväksi paperin laaduntarkastuksessa paperin tuotannon aikana, esimerkiksi kaavinkuvan 7 mukaisesti. Nopealla kameralla otetaan kuvia liikkuvasta paperirainasta 74 paperikoneen 75 yhteydessä. Kuvan kaaviossa on esitetty taustavalon 73, tarpeesta riippuen voidaan käyttää myös esimerkiksi vinoa etuvaloa. Kuville suoritetaan nopea analyysi. Tämän jälkeen voidaan tehdä päätelmiä tuotannossa olevan paperin laadullisista ominaisuuksista ja mahdollisesti säätää prosessin kulkua. Nyt esiteltävää menetelmää käytettäisiin kuvassa olevan tietokoneen 71 yhteydessä. Nopea kuva-analyysi sekä havainnollinen käyttöliittymä suurelle mittausdatalle tarjoavat suunnanomasti lisää informaatiota valmistettavasta paperista itse paperin valmistajalle.

20

Kuva-analyysissä otetuista kuvista irrotetaan piirteitä edellä mainituilla tekniikoilla sekä suoritetaan luokittelu eri laatuluokkiin. Käyttöliittymän avulla voi seurata paperin laadun kehittymistä tuotannon edetessä.

- 25 Menetelmällä voidaan analysoida paperia miltei koko sen tuotantokäsen ajan. Taustavalon tehoa täytyy kuitenkin kasvattaa jos kuvia otetaan jo päällystystä paperista. Lisäksi tekstuuripiirteiden suorituskkyky saattaa kärsiä päällystetyillä papereilla.

Tarkka tieto paperin laadusta sen tuorannon aikana helpottaa paperin valmistajan tekemiä tutkimuksia. Automaatiovalmistaja voi yhdistää järjestelmän osaksi koko prosessia, ja sen sääntöä.

- 5 Keksinnölle on tunnusomaista se, mitä on esitetty itsenäisissä patenttivaatimuksissa ja epäitsenäiset vaatimukset kuvaavat sen edullisia suoritusmuotoja.

Patenttivaatimukset

1. Konenäköön perustuva paperin piirteiden karakterisointimenetelmä, **tun-**  
**nettu** siitä, että lukuisten paperinäytteiden kuvista erotetaan paperin omi-  
5 naisuuksia kuvaavia moniulotteisia piirteitä; mainitut piirteet annetaan syöt-  
teenä ohjaamattomasti toimivaan oppivaan luokittelijaan, joka tuottaa kuva-  
uksen mainitusta kunkin kuvan osan datasta pienempiulotteiseen avaruuteen  
sitä, että ominaisuuksiltaan lähekkäiset paperilaadut tuollavat mainittuun  
pienempiulotteiseen avaruuteen lähekkäiset kuvaukset ja pienempiulottei-  
10 seen avaruuteen kuvautuvia luokittelutuloksia käytetään luokittelun apuna.
2. Vaatimuksen 1 mukainen paperin karakterisointimenetelmä, **tunnettu**  
siltä, että mainittu ohjaamattomasti toimiva oppiva järjestelmä on valvoma-  
ton klusterointimenetelmä tai sen simulaatio, esimerkiksi SOM (Self Or-  
15 ganizing Map).
3. Vaatimuksen 1 tai 2 mukainen paperin karakterisointimenetelmä, **tunnet-**  
**tu** siitä, että paperinäytteitä kuvaava piirre on LBP (Local Binary Pattern) tai  
siltä johdettu bittikuvopiirre.  
20
4. Jonkin edellä olevan vaatimuksen mukainen paperin piirteiden karakte-  
risointimenetelmä, **tunnettu** siltä, että menetelmän mukaan lisäksi kuvataan  
ja luokitellaan paperia sen valmistuksen eri vaiheissa.
- 25 5. Vaatimuksen 4 mukainen paperin piirteiden karakterisointimenetelmä,  
**tunnettu** siltä, että eri valmistuksen vaiheissa kuvattuja näytteitä käsitellään  
saman paperin osalta edelleen ohjaamattomalla oppivalla luokittelijalla niin,  
että luokittelu koskee myös valmistusprosessin kulkua.

6. Vaatimuksen 5 mukainen järjestelmä, **tunnettu** siitä, että kuvainformaation lisäksi luokittelun syötteenä käytetään valittuja prosessiparametreja ja/tai mittaustuloksia.

- 5 7. Järjestelmä paperin luokittelemiseksi konenäköä käyttäen, **tunnettu** siitä, että järjestelmässä on kuvaamisvälineet, välineet paperin laatua kuvaavien piirteiden irrottamiseksi paperin kuvasla ja välineet ohjaamattomasti oppi vaan luokitteluun piirreavaruutta pienempiulotteiseen avaruuteen.

## Liite: Kirjallisuusviiteluettelo

- 5 [1] Cresson T.M., Tomimatsu H. & Luner P. (1990) Characterization of Paper Formation, Part 1: Sensing Paper Formation. Tappi Journal: Vol. 73, No. 7: s. 153-159.
- 10 [2] Cresson T. & Luner P. (1990) Characterization of Paper Formation, Part 2: The Texture Analysis of Paper Formation. Tappi Journal: Vol. 73, No. 12: s. 175-184.
- [2] Cresson T. & Luner P. (1991) Characterization of Paper Formation, Part 3: The Use of Texture Maps to Describe Paper Formation. Tappi Journal: Vol. 74, No. 2: s. 167-175.
- 15 [3] Sudhakara R.P., Stridhar R., Gopal A., Meenakshi K., Revathy R., Chitra K. & Palanlandi D. (2001) Optical Paper Formation Analyzer. CEERI Centre, India.
- 20 [4] Bernie J.P. & Douglas W.J.M. (1996) Local Grammage Distribution and Formation of Paper by Light Transmission Image Analysis. Tappi Journal: Vol. 79, No. 1: s. 193-202.
- 25 [5] Bouyndain M., Colom J.F., Navaro R. & Pladellorens J. (2001) Determination of Paper Formation by Fourier Analysis of Light Transmission Images. Appita Journal: Vol. 54, No. 2: s. 103-105, 115.
- [6] Kohonen T. (1997) Self-organizing Maps. Springer-Verlag, Berlin, Saksa, 426 s.

[7] Roweis S.T. & Saul L.K. (2000) Nonlinear Dimensionality Reduction by Locally Linear Embedding. Science Magazine, Vol 290, 22 December 2000: s. 2323-2326.

5 [8] Roweis S.T. & Saul L.K. (2001) An Introduction to Locally Linear Embedding. URL: <http://www.cs.toronto.edu/~roweis/lle/papers/lleintroa4.pdf> (13.5.2002).

[9] Svensen J.F.M. (1998) GTM: The Generative Topographic Mapping. Väitöskirja. Aston University, Englanti, 108 s.

[10] Tenenbaum J.B. (1998) Mapping a Manifold of Perceptual Observations. Advances in Neural Information Processing Systems, Vol. 10.

15 [11] Ojala T., Pietikäinen M. & Harwood D. (1996) A Comparative Study of Texture Measures With Classification Based on Feature Distributions. Pattern Recognition, Vol. 29, No. 1, s. 51-59.

[12] Ojala T., Pietikäinen M. & Mäenpää T. (2002) Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 24, No. 7.

[13] Kohonen T. (1997) Self-organizing Maps. Springer-Verlag, Berlin, Saksa, 426 s.

25

**(57) Tiivistelmä**

Menetelmä ja järjestelmä paperin karakterisointiin, jossa lukuisten paperinäytteiden kuvista irrotetaan paperin ominaisuuksia kuvaavia moniulotteisia piirteitä; mainitut piirteet annetaan syötteenä ohjaamattomasti toimivaan oppivaan luokittelijaan, joka tuottaa kuvauksen mainitusta kunkin kuvan osan datasta pienempiulotteiseen avaruuteen siten, että ominaisuuksiltaan lähekkäiset paperilaadut tuottavat mainittuun pienempiulotteiseen avaruuteen lähekkäiset kuvaukset ja pienempiulotteiseen avaruuteen kuvautuvia luokittelutuloksia käytetään luokittelun apuna



Fig.1 ja Fig.2. Piirreavaruuden pirstoutuminen ja klusteroituminen

Piirteiden pirstoutuminen




Fig.1

Moniulotteisen piirredatan klusteroituminen kaksikulotteiseen koordinaatistoon




Fig.2

Paperin karakterisointi käyttäen ohjaamattomasti opetettavaa lukolttelija

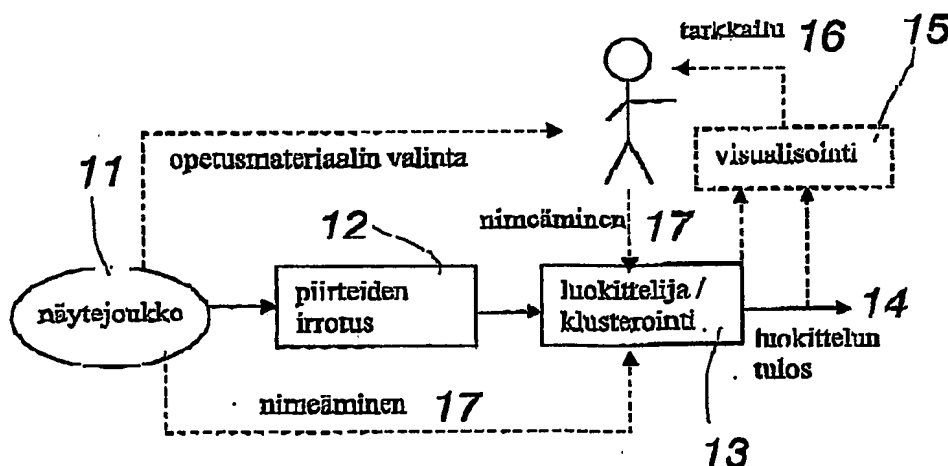



Fig.3

# Alkuperäisen LBP-pisteen laskeminen




## Fig.4

24

3

*Pisteen ympyrän kehällä oleva naapurusto, josta LBP-piirre lasketaan*



*Fig.5*

24

4




Fig.6

*Kaaviokuva konenäköjärjestelmästä tuotannon aikana suoritettavaan paperin karakterisointiin*

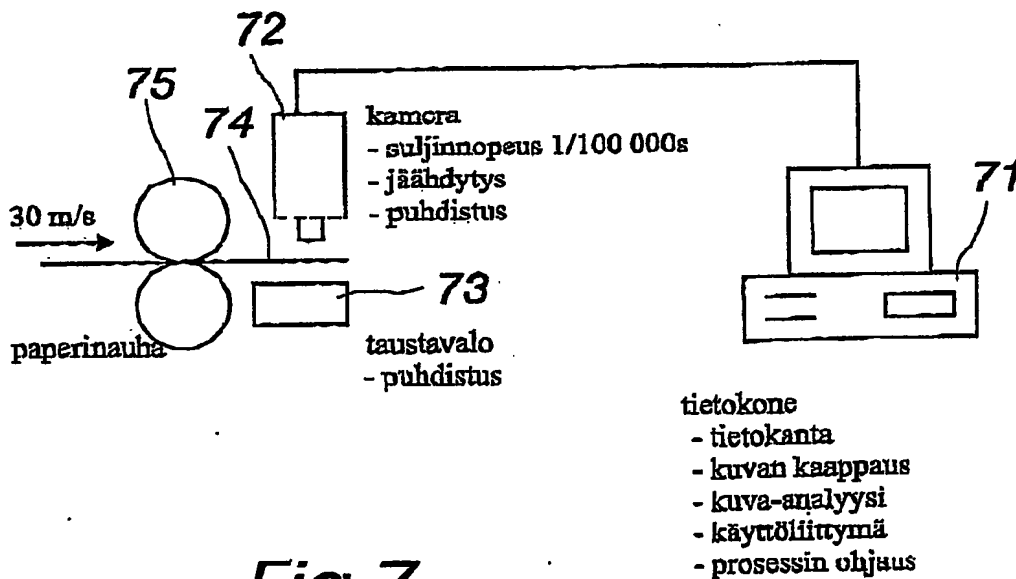


Fig.7